# ESTIMAÇÃO INTERVALAR

Inferência Estatística I Professora: Renata S. Bueno

# Introdução

- Ao invés de estimar o valor real de um parâmetro através de um número, poderíamos pensar em estimar um intervalo que pode conter este valor real.
- Neste caso, falamos em estimação intervalar.
- Por exemplo, estima-se que o número de desempregados em certa área seja 2,4 + ou – 0,3 milhões.
- Estamos quase certos de que o número real de desempregados esteja entre 2,1 e 2,7 milhões.

**Definição:** Seja  $X = (X_1, ..., X_n)$  uma amostra aleatória de uma variável com distribuição que depende de um parâmetro  $\theta$ . Seja  $g(\theta)$  uma função de  $\theta$ . Considere  $T_1 = t_1(X_1, ..., X_n)$  e  $T_2 = t_2(X_1, ..., X_n)$  duas estatísticas satisfazendo  $T_1 \leq T_2$  que possuem a seguinte propriedade para todos os valores de  $\theta$ :

$$P(T_1 < g(\theta) < T_2) \ge \gamma.$$

O intervalo  $(T_1, T_2)$  é chamado de intervalo de confiança de  $\gamma$  para  $g(\theta)$ . Pode ser chamado também de intervalo de confiança de  $\gamma 100\%$  para  $g(\theta)$ .

Se a inequação " $\geq \gamma$ " for uma igualdade para todo  $\theta$ , o intervalo de confiança é chamado exato.

Depois dos valores das variáveis aleatórias  $X_1, ..., X_n$  serem observados, os valores  $T_1 = t_1$  e  $T_2 = t_2$  são computados e o intervalo  $(t_1, t_2)$  é chamado de valor observado do intervalo de confiança.

**Observação**: Existe a possibilidade de que uma das duas estatísticas  $T_1$  ou  $T_2$  seja constante (somente uma delas). Em outras palavras, um dos dois limites do intervalo aleatório  $(T_1, T_2)$  poderia ser constante.

**Definição**: Intervalo de confiança unilateral.

Seja  $X_1, ..., X_n$  uma amostra aleatória da função de densidade (ou de probabilidade)  $f(x|\theta)$ . Considere a estatística  $T_1 = t_1(X_1, ..., X_n)$  tal que

$$P(T_1 < \tau(\theta)) \ge \gamma,$$

então  $T_1$  é chamado de limite unilateral inferior de confiança para  $\tau(\theta)$ .

Similarmente, considere a estatística  $T_2 = t_2(X_1, ..., X_n)$  tal que

$$P(\tau(\theta) < T_2) \ge \gamma,$$

então  $T_2$  é chamado de limite unilateral superior de confiança para  $\tau(\theta)$ 

Renata S. Bueno – Inferência Estatística I (ENCE)

**Exemplo 11.1**: Suponha que  $X_1, X_2, X_3, X_4$  é uma amostra aleatória de 4 observações obtidas de uma população  $N(\mu, 9)$ . Considere:  $X_1 = 1,2; X_2 = 3,4; X_3 = 0,6; e <math>X_4 = 5,6$ .

O EMV de  $\mu$  é  $\bar{X}=2,7$ . Queremos determinar os limites inferior e superior que formam um intervalo que pode conter o verdadeiro valor de  $\mu$ .

Note que

$$Z = \frac{\bar{X} - \mu}{\sqrt{9/n}} = \frac{\bar{X} - \mu}{\sqrt{9/4}} = \frac{\bar{X} - \mu}{3/2} \sim N(0,1).$$

A função de densidade desta variável não depende do parâmetro  $\mu$ . Portanto, podemos calcular a probabilidade de Z estar entre dois quaisquer número  $l_1 < l_2$ . Seja,

$$P(-1.96 < Z < 1.96) = 0.95,$$

Portanto, temos que

$$P\left(\bar{X}-1,96\left(\frac{3}{2}\right)<\mu<\bar{X}+1,96\left(\frac{3}{2}\right)\right)=0,95.$$

Substituindo  $\bar{X} = 2.7$  temos

$$P(-0.24 < \mu < 5.64) = 0.95.$$

O intervalo aleatório  $\left[ \overline{X} - 1,96 \left( \frac{3}{2} \right); \overline{X} + 1,96 \left( \frac{3}{2} \right) \right]$  e o resultado [-0,24;5,64] são chamados de intervalo de confiança de 95%. Cuidado!

Fique atento ao seguinte detalhe: O intervalo [-0,24; 5,64] é uma observação obtida do intervalo aleatório  $\left[\bar{X}-1,96\left(\frac{3}{2}\right); \bar{X}+1,96\left(\frac{3}{2}\right)\right]$  quando usamos o resultado amostral  $\bar{X}=2,7$ .

Se a amostra mudar, será obtido outro valor para  $\overline{X}$  e, consequentemente, o intervalo resultante será diferente de [-0,24;5,64].

Uma interpretação apropriada para  $\left[ \overline{X} - 1,96 \left( \frac{3}{2} \right); \overline{X} + 1,96 \left( \frac{3}{2} \right) \right]$  será: "a probabilidade de que neste intervalo aleatório contenha o valor real (desconhecido) de  $\mu$  é de 0,95".

$X_1$	$X_2$	$X_3$	$X_4$	$\overline{X}$	$[\overline{X}-1,96(3/2);\overline{X}+1,96(3/2)]$
1,2	3,4	0,6	5,6	2,7	[-0,24; 5,64]
3,9	2,1	4,5	3,1	3,4	[ 0,46 ; 6,34]
-1,4	1,0	-2,1	-2,0	-1,1	[-4,04 ; 1,84]
:	:	:	:	:	<b>:</b>

Nesta tabela espera-se que aproximadamente 95% dos intervalos calculados contenham o valor verdadeiro de  $\mu$ .

Tem-se, portanto, 95% de confiança de que o intervalo observado neste problema [-0,24;5,64] irá conter a verdadeira média  $\mu$ .

A medida de nossa confiança é, neste caso, 0,95 (também chamada de coeficiente de confiança)

- Um intervalo com qualquer grau desejado de confiança pode ser obtido.
- Na verdade, é possível construir inúmeros intervalos com o mesmo coeficiente de confiança.

- Iremos preferir aquele intervalo de confiança que for mais curto, isto é, escolhemos " $t_1$ " e " $t_2$ " o mais próximo possível um do outro de forma que a igualdade  $P(t_1 < Z < t_2) = 0,95$  se mantenha válida.
- No caso da distribuição N(0,1), dada sua simetria em relação a zero, a escolha de  $(t_1,t_2)$  que minimiza a amplitude  $t_2-t_1$  para uma área de probabilidade fixada será  $t_2=-t_1$ .

**Observação**: Dado um intervalo de confiança de 100  $\gamma$ % para  $\theta$ , temos que um intervalo de confiança de 100  $\gamma$ % para  $\tau(\theta)$  pode ser obtido aplicando a função  $\tau(\cdot)$ .

**Restrição**:  $\tau(\cdot)$  deve ser função estritamente monótona.

**Exemplo 11.2**: Se  $\tau(\cdot)$  é uma função monótona crescente e  $(T_1, T_2)$  é um intervalo de confiança de 100  $\gamma$ % para  $\theta$ , então  $(\tau(T_1), \tau(T_2))$  é um intervalo de confiança de 100  $\gamma$ % para  $\tau(\theta)$  visto que:

$$P[\tau(T_1) < \tau(\theta) < \tau(T_2)] = P[T_1 < \theta < T_2] = \gamma.$$

- Vamos descrever um método para encontrar intervalos de confiança.
- Assume-se uma amostra aleatória  $X_1, ..., X_n$  de alguma função de densidade (ou de probabilidade)  $f(x|\theta)$  indexada pelo parâmetro  $\theta$ .
- > O objetivo é encontrar um intervalo de confiança estimado para  $\tau(\theta)$  que é uma função real de  $\theta$  ( $\theta$  pode ser um vetor de parâmetros).

**Definição**: Seja  $X_1, ..., X_n$  uma amostra aleatória de  $f(x|\theta)$ . Considere  $Q = q(X_1, ..., X_n, \theta)$ , isto é, Q é uma função de  $X_1, ..., X_n$  e  $\theta$ . Se Q tem distribuição que não depende de  $\theta$ , então Q é chamado de quantidade pivotal.

**Exemplo 11.3**: Seja  $X_1, ..., X_n$  uma amostra aleatória da distribuição  $N(\theta, 9)$ . Qual seria uma quantidade pivotal neste caso?

Usaremos a quantidade pivotal para obter um intervalo de confiança.

#### Método da quantidade pivotal:

Se  $Q = q(X_1, ..., X_n, \theta)$  é uma quantidade pivotal, então Q tem distribuição que não depende de  $\theta$ . Para qualquer  $0 < \gamma < 1$  fixo, existirá  $q_1$  e  $q_2$  dependendo de  $\gamma$  tal que

$$P(q_1 < Q < q_2) = \gamma.$$

Se para cada possível amostra  $(x_1, ..., x_n)$  temos:

$$q_1 < q(X_1, ..., X_n, \theta) < q_2 \iff t_1(X_1, ..., X_n) < \tau(\theta) < t_2(X_1, ..., X_n),$$

sendo  $t_1$  e  $t_2$  funções que não dependem de  $\theta$ , então  $(t_1(X_1,...,X_n),\ t_2(X_1,...,X_n))$  é um intervalo de confiança de  $100\,\gamma\,\%$  para  $\tau(\theta)$ .

#### Alguns comentários:

- 1.  $q_1$  e  $q_2$  não dependem de  $\theta$ .
- Para uma escolha de  $\gamma$ , existem muitos possíveis pares de números  $(q_1, q_2)$  que levam ao resultado  $P[q_1 < Q < q_2] = \gamma$ .
- Diferentes pares  $(q_1, q_2)$  irão fornecer diferentes funções  $t_1$  e  $t_2$ .
- 4. Deveríamos tentar selecionar aquele par  $(q_1, q_2)$  que faz  $t_1$  e  $t_2$  serem o mais próximo possível um do outro.

A característica principal do método da quantidade pivotal é que a desigualdade  $q_1 < q(X_1, ..., X_n, \theta) < q_2$  pode ser reescrita como  $t_1(X_1, ..., X_n) < \tau(\theta) < t_2(X_1, ..., X_n)$  para qualquer possível amostra  $(x_1, ..., x_n)$ .

**Exemplo 11.4**: Seja  $X_1, ..., X_n$  uma amostra aleatória da  $N(\theta, 1)$ . Nosso objetivo é encontrar um estimador intervalar usando o método da quantidade pivotal para estimar  $\tau(\theta) = \theta$ .

**Exemplo 11.5**: Seja  $X_1, ..., X_n$  uma amostra aleatória da  $N(\mu, \sigma^2)$ . Encontre um intervalo de confiança para  $\mu$  usando o método da quantidade pivotal quando  $\sigma^2$  é conhecido e desconhecido.

### Exemplos

**Exemplo 11.6**: Seja  $X_1, ..., X_n$  uma amostra aleatória da  $N(\mu, \sigma^2)$ . Encontre um intervalo de confiança para  $\sigma^2$  usando o método da quantidade pivotal supondo que  $\mu$  é desconhecido.

**Exemplo 11.7**: Seja  $X_1, ..., X_n$  uma amostra aleatória da  $\text{Exp}(\theta)$ . Encontre uma quantidade pivotal para  $\theta$  e construa um intervalo de confiança para  $\theta$ .

**Exemplo 11.8**: Seja  $X_1, ..., X_n$  uma amostra aleatória da  $U(0, \theta)$ . Verifique se  $\frac{X_{(n)}}{\theta}$  é uma quantidade pivotal para  $\theta$ . Construa um intervalo de confiança para  $\theta$  considerando que as probabilidades das caudas são iguais.

- Vamos considerar o caso em que temos  $X_1, ..., X_n$  uma amostra aleatória da variável aleatória  $X \sim N(\mu_1, \sigma^2)$  e  $Y_1, ..., Y_m$ , uma amostra aleatória da variável aleatória  $Y \sim N(\mu_2, \sigma^2)$ , onde X e Y são independentes.
- Suponha que existe interesse em estimar a quantidade  $\theta = \mu_1 \mu_2$ .
- Verifique se  $\bar{X} \bar{Y}$  é um estimador não viciado para  $\theta$ .
- $\triangleright$  Como poderíamos construir um intervalo de confiança para  $\theta$ ?

Sabemos que

$$\bar{X} - \bar{Y} \sim N\left(\mu_1 - \mu_2, \sigma^2\left(\frac{1}{n} + \frac{1}{m}\right)\right)$$

de modo que, sendo  $\theta = \mu_1 - \mu_2$ , consideramos a quantidade pivotal

$$Q(\mathbf{X}, \mathbf{Y}, \theta) = \frac{(\overline{X} - \overline{Y}) - (\mu_1 - \mu_2)}{\sigma \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim N(0, 1).$$

> Sendo  $\sigma^2$  conhecido, temos, o intervalo:

$$\left[ \overline{X} - \overline{Y} - z_{\frac{1+\gamma}{2}} \sigma \sqrt{\frac{1}{n} + \frac{1}{m}} ; \overline{X} - \overline{Y} + z_{\frac{1+\gamma}{2}} \sigma \sqrt{\frac{1}{n} + \frac{1}{m}} \right].$$

> Sendo  $\sigma^2$  desconhecido, temos que uma quantidade pivotal é dada por:

$$Q(\mathbf{X}, \mathbf{Y}, \theta) = \frac{(\overline{X} - \overline{Y}) - (\mu_1 - \mu_2)}{S_p \sqrt{\frac{1}{n} + \frac{1}{m}}}.$$

Onde

$$S_p^2 = \frac{(n-1)S_\chi^2 + (m-1)S_y^2}{(n+m-2)}$$
;  $S_\chi^2 = \frac{1}{n-1}\sum_{i=1}^n (X_i - \bar{X})^2$ 

e 
$$S_y^2 = \frac{1}{m-1} \sum_{i=1}^n (Y_i - \overline{Y})^2$$
.

Como  $\frac{(n-1)S_x^2}{\sigma^2} \sim \chi_{n-1}^2$  e  $\frac{(m-1)S_y^2}{\sigma^2} \sim \chi_{m-1}^2$ , pela independência de  $S_x^2$  e  $S_y^2$  temos que

$$\frac{(n+m-2)S_p^2}{\sigma^2} \sim \chi_{n+m-2}^2.$$

 $\triangleright$  Então, um intervalo de  $\gamma$  de confiança para  $\theta$  é dado por:

$$\left[ \bar{X} - \bar{Y} - t_{\frac{1+\gamma}{2};n+m-2} S_p \sqrt{\frac{1}{n} + \frac{1}{m}} \; ; \; \bar{X} - \bar{Y} + t_{\frac{1+\gamma}{2};n+m-2} S_p \sqrt{\frac{1}{n} + \frac{1}{m}} \right].$$

> Como ficaria o intervalo de confiança para  $\sigma^2$ ?

Suponha que temos  $X_1, ..., X_n$  uma amostra aleatória de  $X \sim N(\mu_1, \sigma_1^2)$  e  $Y_1, ..., Y_m$ , uma amostra aleatória de  $Y \sim N(\mu_2, \sigma_2^2)$ , onde X e Y são independentes, e o interesse é a construção de um intervalo de confiança para  $\sigma_1^2/\sigma_2^2$ .

Note que

$$\frac{(n-1)S_{\chi}^2}{\sigma_1^2} \sim \chi_{n-1}^2 \ \ \text{e} \ \ \frac{(m-1)S_y^2}{\sigma_2^2} \sim \chi_{m-1}^2.$$

Sendo assim, temos a seguinte quantidade pivotal:

$$Q(X,Y,\theta) = \frac{(m-1)S_y^2/\sigma_2^2(m-1)}{(n-1)S_x^2/\sigma_1^2(n-1)} \sim F_{m-1,n-1},$$

onde  $F_{m-1,n-1}$  denota a distribuição F com m-1 e n-1 graus de liberdade.

ho Então, dado γ, obtemos  $\lambda_1$  e  $\lambda_2$  na distribuição  $F_{m-1,n-1}$ , de modo que

$$P\left[\lambda_1 \leq \frac{\sigma_1^2 S_y^2}{\sigma_2^2 S_x^2} \leq \lambda_2\right] = \gamma.$$

Considerando o intervalo com probabilidade iguais para as caudas, ou seja,  $\lambda_1 = F_1$  e  $\lambda_2 = F_2$ , de modo que

$$P[F_{m-1,n-1} \ge F_2] = P[F_{m-1,n-1} \le F_1] = (1 - \gamma)/2,$$

onde  $F_1$  e  $F_2$  são obtidos na tabela da distribuição F com m-1 e n-1 graus de liberdade, temos o intervalo

$$\left[F_1 \frac{S_x^2}{S_y^2} ; F_2 \frac{S_x^2}{S_y^2}\right].$$